

# Machine Learning per la Manutenzione Predittiva: l'impatto del progetto SIMPLE

Lorenzo Bianchini, Alessandra Capriotti, Rosario Capparuccia, Mauro Parrini, Luca Romeo, Riccardo Rosati, Emanuele Frontoni

Sigma spa,

Nuova Simonelli srl,

VRAI, Department of Information Engineering Università Politecnica delle Marche,

VRAI, Università di Macerata,

{lbianchini, acapriotti, rcapparuccia}@sigmaspa.com, mauro.parrini@simonelligroup.it, {l.romeo, r.rosati}@univpm.it, emanuele.frontoni@unimc.it

## Abstract

Il progetto “Smart Manufacturing Machine with Predictive Lifetime Electronic maintenance (SIMPLE) coinvolge differenti aziende del territorio marchigiano. L’obiettivo del progetto è quello di realizzare innovativi prodotti monitorabili e controllabili sia in locale che da remoto, in grado di implementare logiche di manutenzione predittiva, connessi ad una nuova piattaforma. Gli algoritmi di manutenzione predittiva sviluppati sono basati su dataset opportunamente acquisiti e su modelli di Machine Learning. Nel seguente manoscritto si evidenziano in particolare i risultati di due casi d’uso che sono stati studiati ed affrontati nell’ambito del progetto: manutenzione predittiva per ascensore monete sensorizzato e per log ATM.

## 1 Introduction

Il progetto “Smart Manufacturing Machine with Predictive Lifetime Electronic maintenance (SIMPLE) è promosso dalle seguenti aziende del territorio marchigiano Sigma spa, Clabo spa, Simonelli Group spa, Schnell spa, Peralisi Maip spa, con la collaborazione dell’Università Politecnica delle Marche e Università di Camerino. L’obiettivo del progetto è di realizzare prodotti innovativi, monitorabili e controllabili sia in locale sia da remoto, in grado di implementare logiche di manutenzione predittiva e collegati ad un’inedita piattaforma utilizzabile in diversi contesti industriali. I vari apparati connessi(ATM, ticket vending machine, macchine da caffè, centrifughe, banchi frigo, staffatrici) saranno dotati di apposita sensoristica e trasferiranno i dati necessari alla piattaforma, concepita con l’obiettivo di garantire il monitoraggio delle condizioni di funzionamento dei dispositivi collegati ed integrare funzionalità per la previsione di guasto degli stessi. Nello specifico la piattaforma oggetto di studio è così caratterizzata:

- Integrata e basata su servizi message-oriented ed orientata ai micro-servizi;

- Flessibile e facilmente applicabile, con minimi interventi di configurazione, alle diverse tipologie di prodotto oggetto di studio o con differenti condizioni di carico;
- Ad alte performances e facilmente manutenibile;
- Scalabile in maniera facile ed efficiente sia orizzontalmente che verticalmente;
- Dai costi contenuti, tali cioè da non incidere in maniera significativa sul costo totale dell’apparato con il quale verrà integrata.

Lo scopo di questo articolo è presentare sinteticamente le attività svolte, le scelte effettuate ed i risultati ottenuti in relazione alla realizzazione di singoli moduli prototipali finalizzati a validare possibili soluzioni progettuali all’interno del progetto SIMPLE. In particolare, i task svolti possono essere riassunti dai seguenti topic:

- Sensorizzazione di apparati
- Creazione di prototipi e banchi di prova per acquisizione dei dati finalizzati alla creazione dei dataset
- Implementazione prototipi di pipeline di trattamento dati con algoritmi di Machine Learning.

La figura 1 riporta i passi principali di un generico processo di definizione ed utilizzo di modelli di ML. Come si vede dalle frecce centrali, si tratta di un processo iterativo che non si esaurisce al primo passaggio ma ha bisogno di revisioni, adattamenti e migliorie. Nell’ambito del progetto SIMPLE sono stati sperimentati modelli diversi partendo da dati e problematiche riferite a diversi scenari applicativi descritte nelle successive sezioni (casi d’uso ascensori e ATM).

Algoritmi data-driven per la manutenzione predittiva imparano il normale comportamento dei dati di una macchina e li utilizzano come base di riferimento per identificare e segnalare le deviazioni in tempo reale. Gli algoritmi necessari per l’apprendimento della macchina devono analizzare i dati in ingresso (serie storiche) e i dati in uscita (target desiderato). Un sistema di monitoraggio della macchina include input su una serie di fattori che vanno per esempio dalla temperatura alla pressione. L’output è la variabile in questione ovvero un’avvertenza di un guasto futuro del sistema o del macchinario oppure il tempo

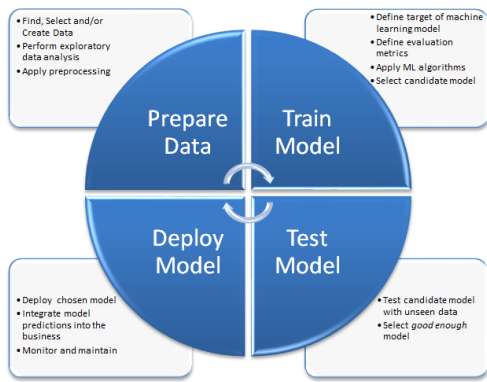


Figura 1: Processo generale per la costruzione di un modello di ML per PdM

di vita dell'utensile o macchinario [Calabrese *et al.*, 2020; Paolanti *et al.*, 2018]. Il sistema sarà quindi in grado di prevedere quando è probabile che si verifichi un guasto o di stimare il tempo di vita dell'utensile o del macchinario. I due approcci di machine learning principali per risolvere questi task che si possono trovare in letteratura sono: apprendimento automatico supervisionato e non supervisionato. Le due categorie di approcci possono essere rilevanti per un diverso scenario e dipendono dalla disponibilità di sufficienti dati storici di formazione e dalla frequenza del guasto degli apparecchi.

## 2 Prototipo di acquisizione dati da ascensore monete sensorizzato e generazione dataset per primi test sperimentali

Il dispositivo oggetto dell'analisi consiste in un sistema di sollevamento monete, sottogruppo di un apparato di ticketing, costituito da un nastro di trasporto dentato con facchini in poliuretano e trasmissione principale composta da un motoriduttore a vite senza fine e da cinghia e pulegge dentate. Si è deciso di sensorizzare questo dispositivo ed applicare tecniche di predictive maintenance perché un guasto su questo dispositivo ha un forte impatto sulla user experience dell'utente finale: infatti un fuori servizio non rilevabile sull'ascensore monete si traduce in una mancata erogazione di denaro/resto. Dall'esperienza del reparto manutenzione di Sigma è emerso che i principali problemi che si possono avere sull'ascensore monete sono:

- rumorosità;
- assorbimento del motore fuori range;
- cinghia deteriorata o danneggiata;
- encoder rotto / non funzionante;
- mancata presa delle monete da parte della cinghia.

La figura 2 mostra il banco, appositamente progettato per ospitare gli ascensori monete, utilizzato per l'acquisizione dei dati dei moduli rientrati in riparazione. I dati acquisiti nelle 2 fasi di pre e post riparazione sono accelerazioni (massime e minimo) acquisiti da due accelerometri posizionati nell'e-

stremità superiore ed inferiore dell'ascensore e assorbimento (massimo e minimo).



Figura 2: Banco realizzato per ospitare gli ascensori monete durante le acquisizioni fatte in casa

I dati acquisiti sono stati estratti per ottenere un dataset su cui poter compiere test di elaborazione a vario livello. In particolare si è deciso, come primo passo, di valutare il peso delle diverse caratteristiche per l'addestramento dei modelli più utilizzati di ML tramite metodi di features selection. Si è proceduto poi all'implementazione di algoritmi di Machine Learning per l'identificazione dei tre stati anomali: "assorbimento fuori range", "rumoroso" e "post-produzione". La procedura di splitting implementata è una 10 fold cross validazione con una procedura 5 fold cross validazione per la validazione interna degli iperparametri dei modelli di ML. Si presentano in figura 3 i risultati in termini di matrici di confusione degli approcci di ML testati sul dataset di riferimento.

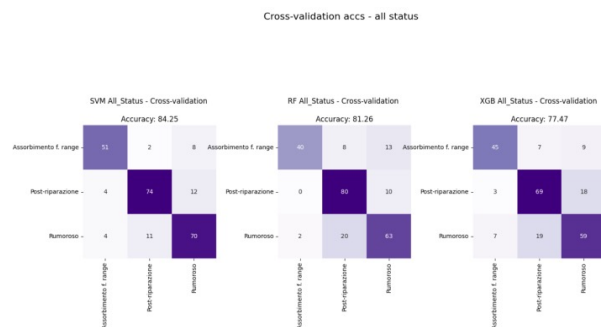


Figura 3: Matrice di confusione approcci per l'identificazione dei tre stati anomali: "assorbimento fuori range", "rumoroso" e "post-produzione": Support Vector Machine (SVM), Random Forest (RF), XGB

### 3 Prototipo di acquisizione dati da log ATM, parserizzazione e generazione dataset

Gli apparati ATM generano una grandissima quantità di log per ciascuna periferica. Questi file possono contenere tutte le informazioni riguardo il funzionamento dei singoli dispositivi e sono normalmente scritti in modalità verbose per consentire di analizzare eventuali comportamenti anomali, ma, in genere, non è richiesto che siano strutturati secondo rigide regole. Nel caso del progetto SIMPLE si è proceduto a razionalizzare il processo di logging implementando una soluzione evoluta di log management con caratteristiche di aggregazione e storage, trasferimento sicuro, parsing automatico e trasformazione dei log in dati. Inoltre è stata svolta un'attività di estrazione dei dati degli interventi tecnici, sia conseguenti a chiamate per malfunzionamenti, sia legati ad attività di manutenzione preventiva, dal sistema di gestione ticket di Sigma. Quindi le informazioni provenienti dai log e dal server di manutenzione sono state riconciliate tramite operazioni automatiche (tramite batch appositamente sviluppati per correlare i dati per macchine/date) e manuali (per etichettare le tipologie di guasti riscontrati dopo aver interpretato le annotazioni non strutturate del tecnico al momento dell'intervento) Dall'incrocio dei dati provenienti da fonti differenti sono stati generati i dataset prototipali. In particolare l'attenzione è stata concentrata su 3 diversi device installati nell'ATM: CRM, badge reader e stampante ricevute.

I dataset estratti dal sistema prototipale di recupero ed analisi dati sono stati usati per validare i primi modelli di Machine Learning finalizzati alla predizione di particolari output individuati di volta in volta per le diverse tipologie di dati. In particolare sono state applicate tecniche di preprocessing (features selection, normalizzazione, rimozione outlier, oversampling e downsampling, smote...) finalizzate ad escludere features ridondanti e irrilevanti al task di manutenzione predittiva.

Il CRM (Cash Recycling Module) è il dispositivo più complesso all'interno dell'ATM in quanto costituito da molte parti meccaniche che devono essere pilotate e mantenute nel miglior modo possibile per evitare problemi in fase di trattamento del denaro. L'elevato numero di features è conseguenza della complessità del dispositivo CRM che deve essere in grado di dispensare banconote sia singole che in bundle dagli ATM (Bancomat) e quindi richiede una meccanica, la relativa sensoristica di controllo/attuazione ed i software di gestione/monitoraggio estremamente sofisticati. Il dataset è costituito da una serie di righe che riportano, per ciascuna giornata di osservazione e per ciascuna macchina monitorata, i valori statistici dei parametri ritenuti di maggiore interesse dagli specialisti.

Il problema può essere quindi riassunto come stima del remaining useful life (RUL). Per la risoluzione quindi sono state valutati due differenti approcci supervisionati: (i) task di regressione (stima continua del RUL) e (ii) task di classificazione (guasto entro 7 giorni e no guasto entro 7 giorni). In tabella 1 sono mostrati i risultati in termini di balanced accuracy relativi all'applicazione del modello Long Short Term Memory (LSTM) [Hochreiter e Schmidhuber, 1997] in un setting one-to-one e un setting many-to-one per la risoluzione



Figura 4: CRM (Cash Recycling Module)

ne del task ii) di classificazione. Si noti come la procedura esterna per la valutazione delle performance dei modelli è una cross-validazione svolta per macchine o per cicli di guasto.

Tabella 1: Risultati sperimentali modello LSTM

Modello	Cross-Validazione	Feature selection	Balanced accuracy
LSTM	macchina	No	0.641
LSTM	cicli	No	0.653
LSTM	macchina	Si	0.638
LSTM	cicli	Si	0.647

L'esperimento con la balanced accuracy più elevata (0.653) ha la seguente confusion matrix: TN=4909, FP=1200, FN=168, TP=170. Tuttavia in questo esperimento i 1200 valori erroneamente classificati come pre-guasto sono un rischio elevato in quanto si dovrà inviare un tecnico ogni volta che rischio di avere un guasto (in questo caso viene inviato 1200 volte senza motivo).

Per ovviare a questo problema, come sviluppo futuro si sta definendo una loss custom che consenta di minimizzare l'F1 e allo stesso tempo avere una balanced accuracy elevata. Questo con l'obiettivo di ridurre maggiormente i falsi positivi rispetto ai falsi negativi (intervenire su macchine che in realtà non hanno un guasto è un costo maggiore per l'azienda rispetto al fatto di mancare un guasto). I successivi esperimenti prima della fase di export del modello ed integrazione in un sistema di support alle decisioni hanno come obiettivo quello di ottenere una valutazione consistente delle performance, eseguendo più esecuzione di cross-validazione ed ottenendo una distribuzione statistica delle performance.

Approcci futuri riguarderanno anche l'applicazione di modelli sequenziali LSTM nell'ottica di modellare ricorrenze temporali all'interno di ogni ciclo di guasto in un setting di modellazione many-to-many. Questo porterebbe all'applicazione di finestre temporali e ad uno zero padding per uniformare le time series in oggetto. Ulteriori approcci saranno sviluppati nell'ottica di includere un setting di multiple instance learning in un approccio sequenziale [Dennis *et al.*, 2018], rilasciando quindi il vincolo di avere un numero di osservazioni costanti per ogni ciclo di guasto.

### 4 Acknowledgment

Decreto n. SGI/21004138 del 15/07/2021, con il quale sono state concesse, per il progetto n. F/130068/01-05X38 di ricerca industriale e sviluppo sperimentale, le agevolazioni a valere sul Programma Operativo Nazionale "Imprese e competitività" 2014-2020 FERS

## Riferimenti bibliografici

- [Calabrese *et al.*, 2020] Matteo Calabrese, Martin Cimmino, Francesca Fiume, Martina Manfrin, Luca Romeo, Silvia Ceccacci, Marina Paolanti, Giuseppe Toscano, Giovanni Ciandrini, Alberto Carrotta, Maura Mengoni, Emanuele Frontoni, e Dimos Kapetis. Sophia: An event-based iot and machine learning architecture for predictive maintenance in industry 4.0. *Information*, 11(4), 2020.
- [Dennis *et al.*, 2018] Don Dennis, Chirag Pabbaraju, Harsha Vardhan Simhadri, e Prateek Jain. Multiple instance learning for efficient sequential data classification on resource-constrained devices. In S. Bengio, H. Wallach, H. Larochelle, K. Grauman, N. Cesa-Bianchi, e R. Garnett, editors, *Advances in Neural Information Processing Systems*, volume 31. Curran Associates, Inc., 2018.
- [Hochreiter e Schmidhuber, 1997] Sepp Hochreiter e Jürgen Schmidhuber. Long short-term memory. *Neural Comput.*, 9(8):1735–1780, nov 1997.
- [Paolanti *et al.*, 2018] Marina Paolanti, Luca Romeo, Andrea Felicetti, Adriano Mancini, Emanuele Frontoni, e Jelena Loncarski. Machine learning approach for predictive maintenance in industry 4.0. In *2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications (MESA)*, pages 1–6. IEEE, 2018.